

3-3 Pi-SAR X2 (航空機 SAR) × 深層学習による土地被覆分類

3-3 Land Cover Classification by Pi-SAR X2 (Airbone SAR) and Deep Learning

有馬悠也

Yuya ARIMA

情報通信研究機構は航空機搭載合成開口レーダー (Pi-SAR X2) で地表の観測を行うとともに、その観測データを有効に活用しやすくするため、機械学習、特に深層学習を用いてデータを処理する方法についても研究を進めている。本稿では Pi-SAR X2 の観測データと地理情報システム (GIS) データから得られた植生データを基に深層学習手法で土地被覆分類を行った結果を報告する。

The National Institute of Information and Communications Technology (NICT) observes the ground surface with the airborne synthetic aperture radar: Pi-SAR X2 and conducts research on methods of processing the observed data using machine learnings, especially deep learnings, in order to make it easy to use effectively. In this paper, we report the result of land cover classification by deep learning based on the observation data of Pi-SAR X2 and the vegetation data obtained from Geographic Information System (GIS) data.

1 まえがき

リモートセンシングは人工衛星や航空機などから地表を観測する技術である。広範囲を観測でき、直接人が立ち入りにくい地域でも観測できるなどの利点がある。観測手段としては可視光や赤外光での撮影やマイクロ波レーダーなどがある。このうち、マイクロ波レーダーには雲や噴煙などの有無に左右されない、昼夜を問わず 24 時間観測可能であるなどの利点がある。

マイクロ波レーダーではアンテナサイズが大きいほどより高い分解能を得られる。しかし、人工衛星や航空機にアンテナを搭載しなければならないリモートセンシングにおいて、その大きさには物理的な制約がある。

合成開口 (Synthetic aperture) とは複数の小さなアンテナで受信された信号を合成することで、仮想的に大きなアンテナで受信したかのような信号を生成する手法である [1]。人工衛星や航空機による合成開口レーダー (Synthetic aperture radar: SAR) では移動する単一のアンテナを用い、時間差で観測した信号で合成開口を行う [2]。これにより、小さいアンテナでも高い空間分解能を実現する。

リモートセンシングには航空機によるものと人工衛星によるものがあり、それぞれ異なる特徴を持つ。航空機 SAR と衛星 SAR の最大の違いはその高度である。航空機 SAR が上空数千 m から 1 万 m の高度を飛行

するのに対し、衛星 SAR は数百 km から千 km の高度を周回している。そのため、衛星 SAR の方が広い範囲を観測することが可能である。また、衛星 SAR は上空を常に周回しているため定期的な観測を行うのに向いている。一方で、航空機 SAR は随時、観測の飛行コースを設定できるため、軌道の決まった衛星に対し電波の入射角や照射方向の設定の自由度が高いという利点がある。また、アンテナの大きさや個数について航空機 SAR の方が制約は少ない。

情報通信研究機構は航空機搭載 SAR である Pi-SAR X2 を 2006 年から開発し運用を行っている。Pi-SAR X2 は X バンド (9 GHz 帯) の SAR で、最高 0.3 m の空間分解能を持つ [3]-[5]。したがって、極めて高精細な地表の観測画像を得ることができる。

しかし、SAR で取得される画像は基本的にモノクロであるため、専門家以外が情報を正確に読み取り、有効に活用することは難しい。

機械学習は人間や多くの生物が自然に持っている学習能力と同様の機能をコンピュータ上で再現しようとする試みであり、古くから様々なアプローチで研究が行われてきた。深層学習は機械学習手法のひとつで、多層のニューラルネットワークによって行われる学習である。近年の計算機の急激な能力向上や、インターネットの発達によって訓練データの調達が可能になったことによって盛んに研究が行われるようになった。深層学習は画像、音声、自然言語などを対象とした分

3 航空機 SAR による地表面の観測

類、回帰、認識などの問題に高い性能を示す [6] [7]。そこで、SAR 観測データを深層学習によって処理することで、情報を利用しやすい形に加工することを考える。

本報告では、Pi-SAR X2 により観測された画像に対し、深層学習による画像分類手法を応用することで植生を含む土地被覆分類を行う。

2 深層学習による Pi-SAR X2 観測データの土地被覆分類手法

Pi-SAR X2 はフルポラリメトリックのデータを取得できる [4]。つまり、水平偏波と垂直偏波の信号をそれぞれ照射し、水平偏波と垂直偏波それぞれのアンテナで受信することで、4つの観測データを取得する。それぞれのデータは水平偏波を H、垂直偏波を V として、送信と受信の組み合わせで HH、HV、VH、VV と表示する。

地表の物体によって散乱される偏波の特性が異なることが知られている。典型的な例として、2回反射散乱が支配的となる人工建造物では、送信と受信の偏波が同じライク偏波 (HH/VV) 成分が卓越し、体積散乱が支配的となる植物などでは送信と受信で偏波が変わるクロス偏波 (HV/VH) 成分が卓越する [8]。このような偏波特性の違いを基準に深層学習を用いて土地被覆分類を行う。つまり、通常の画像分類で RGB の 3 成分を入力するところに、代わりに HH/HV/VH/VV の 4 ch のデータを入力する。




図 1 伊豆諸島神津島南部の Pi-SAR X2 観測データの擬似カラー画像 (R:HH、G:HV、B:VV)。観測日 2011 年 10 月 5 日、中心座標：北緯 34 度 11 分 58 秒、東経 139 度 8 分 13 秒。

深層学習で学習する際の教師ラベル及び学習後の検証の際の正解ラベルは地理情報システム (Geographic information system: GIS) データから取得する。今回は GIS データとして環境省生物多様性センターが提供する「1/25,000 植生図 GIS データ」を用いた [9]。このデータは第 6 回自然環境保全基礎調査 (1999-2004) 及び第 7 回自然環境保全基礎調査 (2005-) に基づいて作成されたもので、現地調査と空中写真判読によって約 900 の植生区分に分類されている。この分類を基に 14 のクラスに統合を行い、ラベルとして用いた。

学習のモデルとして畳み込みニューラルネットワーク (Convolutional neural network: CNN) を採用する。CNN は画像や動画認識に広く使われる深層学習モデルの一種である [10]。5 層の畳み込み層と 3 層の全結合層を持つネットワークを構築し学習を行った。

3 実験

今回の実験では 2011 年 10 月 5 日に観測された伊豆諸島神津島南部の 4 km × 4 km の範囲の観測データを使用した。画像としてのサイズは 16,000 ピクセル × 16,000 ピクセルである。HH 偏波を R 成分、HV 偏波を G 成分、VV 偏波を B 成分として作成した擬似カラー画像を図 1 に示す。この画像で左方向が航空機の進行方向 (アジマス方向)、下方向がレーダーの照射方向 (レンジ方向) である。SAR は航空機から斜め下方向に観測を行っているため、画像には各地点の標高に応じた倒れ込みが生じている。そこで、国土地理院提供の数値標高モデル (Digital elevation model: DEM) [11] を用いて正射投影 (オルソ) 補正を行っている。

ネットワークへの入力としては HH/HV/VH/VV 偏波それぞれの散乱強度画像から切り出した 128 ピクセル × 128 ピクセルのパッチ画像を用いる。パッチは縦横 16 ピクセルずつのスライドで切り出していき、

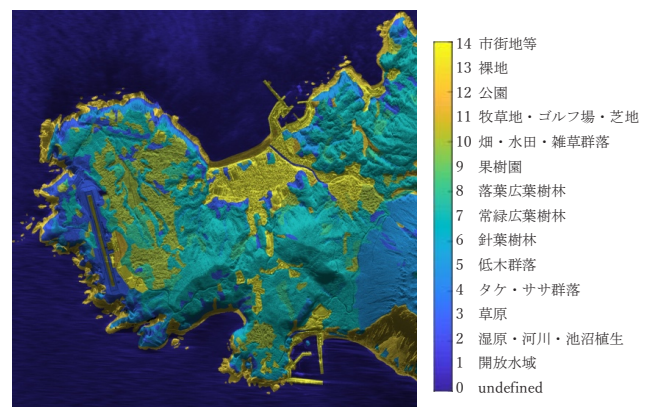


図 2 散乱強度 (HH 偏波) と教師ラベルの重ね合わせ画像

奇数番目を検証用、偶数番目のうちランダムに抽出した 125568 パッチを学習用としている。各パッチ画像には GIS から抽出したラベルを教師として与える。図 2 に HH 偏波の散乱強度画像と GIS データから抽出した教師ラベルを重ねたものを示す。各地点の明るさが散乱強度を示し、色相が教師ラベルの分類クラスを示している。

学習用パッチと教師ラベルを組み合わせた学習データを用いてネットワークの学習を行った。処理ソフトウェアには MATLAB を用いている。学習データに対して 100 回の反復学習を行い、学習にかかった時間はおよそ 5 時間であった。

学習後のネットワークを用いて検証用パッチの分類を行った。分類した結果を図 3 に示す。各色が分類のクラスに対応する。また、分類結果のクロス集計を表 1 に示す。表 1 は各行が GIS データから抽出した正解を示し、各列がネットワークによる分類結果を示しており、各セル内の数字が該当するパッチ数を示している。つまり、縦と横のクラスが一致することが分類結果の正解を意味する。右端の列はクラスごと及び

全体の正答率を示す。

正答率は全体では 79.26 % であった。クラス別で見ると開放水域が最も正答率が高い。図 1 から分かる通り、水面は陸地に比べ散乱強度が明らかに小さいという特徴があるため、分類が容易であったのだと予想される。ただし、画像左側中央付近にある空港の滑走路や、各地にある道路(教師ラベルでは「市街地」に分類されている)、さらに、裸地も散乱強度が低いため多少の誤分類が生じている。続いて市街地も正答率が高く、80 % を超えていた。人工物と植生との偏波特性の違いが分類に有効に働いたのだと考えられる。一方、針葉樹林、常緑広葉樹林、落葉広葉樹林は相互に誤分類が多く、正答率は 50 % 台にとどまった。これはそれぞれのクラスの特徴が近いため十分に分類ができなかったのだと考えられる。また、画像内でクラスに該当する面積が小さく、十分な数の学習データが取れなかった河川・池沼植生、竹林、果樹園はさらに正答率が低かった。




図 3 学習済みネットワークによる検証データの分類結果(右)と正解ラベル(左)

表 1 検証データの分類結果のクロス集計

正解\予測	湿原・河川・池沼													合計	精度(%)	
	開放水域	植生	草原	竹林	低木群落	針葉樹林	常緑広葉樹林	落葉広葉樹林	果樹園	畑・水田・雑草群落	牧草地・ゴルフ場・芝地	公園	裸地			市街地等
1 開放水域	106688	0	118	0	151	17	46	2	0	15	18	0	4648	639	112342	94.97
2 湿原・河川・池沼植生	0	10	3	0	1	0	2	1	0	3	0	0	0	22	42	23.81
3 草原	28	0	6511	1	716	253	854	146	1	465	69	0	796	532	10372	62.77
4 竹林	0	0	3	11	0	5	9	14	0	2	1	0	0	2	47	23.40
5 低木群落	88	0	1166	0	9714	377	1056	131	0	228	71	0	1289	211	14331	67.78
6 針葉樹林	1	0	180	2	137	1826	552	83	0	115	13	0	153	65	3127	58.39
7 常緑広葉樹林	40	1	4460	10	3902	2716	23722	3489	28	3325	412	0	1112	1793	45010	52.70
8 落葉広葉樹林	2	0	209	1	204	126	973	2890	2	412	63	0	95	79	5056	57.16
9 果樹園	0	0	0	1	0	5	14	30	46	34	1	0	0	3	134	34.33
10 畑・水田・雑草群落	11	1	939	7	226	439	1006	778	18	8123	70	0	161	556	12335	65.85
11 牧草地・ゴルフ場・芝地	1	1	49	0	33	20	50	7	0	7	597	0	13	53	831	71.84
12 公園	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	-
13 裸地	581	1	351	0	392	147	180	27	0	85	11	0	11856	355	13989	84.77
14 市街地等	87	1	386	2	123	148	484	98	0	589	74	0	555	12028	14575	82.52
0 undefined	438	3	1962	6	1249	1030	2408	929	21	1555	213	0	2938	2066	14818	-
合計	107965	18	16337	41	16848	7109	31356	8625	116	14958	1613	0	23619	18404	247009	79.26

4 まとめ

この報告では、畳み込みニューラルネットワークによる画像分類手法を Pi-SAR X2 の偏波画像に適用することによって、土地被覆分類を行った。実験により、水域と都市域、植生域は精度良く区分することができることを示した。一方で、植生域内の植物の種類に対する分類精度は不十分であったため、精度を向上するための何らかの工夫が必要であると判明した。また、今回は同一の観測データから学習と検証を行ったが、観測条件の異なるデータに対しても十分な汎化性能が出せるかについて今後検証していく必要がある。

5 謝辞

本解析では環境省生物多様性センターの自然環境調査 Web-GIS 及び国土地理院の数値標高モデルを出典明示の上利用させていただいた。ここに謝意を示します。

【参考文献】

- 1 大内和夫, “リモートセンシングのための合成開口レーダの基礎: Principles of synthetic aperture radar for remote sensing,” 東京電機大学出版局 (2009).
- 2 浦塚清峰, “災害とともに進化してきた航空機搭載合成開口レーダ,” 電子情報通信学会 通信ソサイエティマガジン, 10, 3, pp.196-202, 2016.
- 3 Akitsugu Nadai, Seiho Uratsuka, Toshihiko Umehara, Takeshi Matsuoka, Tatsuharu Kobayashi, and Makoto Satake, “Development of X-band airborne polarimetric and interferometric SAR with sub-meter spatial resolution,” in Geoscience and Remote Sensing Symposium (IGARSS), 2009 IEEE International. IEEE, 2009, vol.2, pp.II-913-II-916.
- 4 Takeshi Matsuoka, Toshihiko Umehara, Akitsugu Nadai, Tatsuharu Kobayashi, Makoto Satake, and Seiho Uratsuka, “Calibration of the high performance airborne sar system (Pi-SAR2),” in Geoscience and Remote Sensing Symposium (IGARSS), 2009 IEEE International. IEEE, 2009, vol.4, pp.IV-582-N-585.
- 5 Junpei Uemoto, Seiho Uratsuka, Toshihiko Umehara, Shin-ichi Yamamoto, Shinichi Taira, Makoto Satake, Shoichiro Kojima, Tatsuharu Kobayashi, Masaki Satoh, Kazuyoshi Kawasaki, et al., “Development of the onboard processor for Pi-SAR2,” in Geoscience and Remote Sensing Symposium (IGARSS), 2011 IEEE International. IEEE, 2011, pp.906-909.
- 6 Yann LeCun, Yoshua Bengio, and Geoffrey Hinton, “Deep learning,” Nature, vol.521, no.7553, pp.436-444, 2015.
- 7 Jürgen Schmidhuber, “Deep learning in neural networks: An overview,” Neural networks, vol.61, pp.85-117, 2015.
- 8 Freeman, Anthony, and Stephen L. Durden. “A three-component scattering model for polarimetric SAR data,” IEEE Transactions on Geoscience and Remote Sensing, 1998, 36.3: pp.963-973.
- 9 “環境省 生物多様性センター 自然環境調査 Web-GIS,” [Online], Available: <http://gis.biodic.go.jp/webgis/>, [Accessed: 10-Dec-2018]
- 10 Yann LeCun, Koray Kavukcuoglu, Clément Faron, et al., “Convolutional networks and applications in vision.,” in ISCV, 2010, vol.2010, pp.253-256.
- 11 “国土地理院 基盤地図情報サイト,” [Online], Available: <http://www.gsi.go.jp/kiban/>, [Accessed: 12-Dec-2018].

有馬悠也 (ありま ゆうや)

電磁波研究所
リモートセンシング研究室
研究員
博士(工学)
電子情報工学・機械学習・マイクロ波